

Peramalan Daya Listrik Jangka Sangat Pendek Pembangkit Termal dengan Metode k-NN-ANN

PERAMALAN DAYA LISTRIK JANGKA SANGAT PENDEK PEMBANGKIT TERMAL BERDASARKAN DATA METEOROLOGI MENGGUNAKAN METODE *k*-NEAREST NEIGHBOR-ARTIFICIAL NEURAL NETWORK

Dwi Ardianto

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
e-mail : dwiardianto@mhs.unesa.ac.id

Unit Three Kartini.

Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
e-mail : unitthree@unesa.ac.id

Abstrak

Penyediaan daya listrik yang terencana sangat diperlukan untuk menghindari kelebihan atau kekurangan daya yang besar hasil dari pembangkit untuk memasok kebutuhan konsumen. Metode hybrid *k*-Nearest Neighbour (*k*-NN) - Artificial Neural Network (ANN) digunakan dalam peramalan jangka sangat pendek pembangkit termal. Penelitian ini bertujuan membahas tentang peramalan nilai daya listrik yang akan dibangkitkan oleh pembangkit termal yang ditargetkan dalam satu jam ke depan. Pembangkit termal yang menjadi target peramalan pada penelitian ini letaknya saling berdekatan dengan pembangkit termal dan hidro yang lain. Hasil penelitian menunjukkan nilai *Mean Absolute Deviation* (MAD) dengan metode *k*-NN sebesar 246,61 MW dan nilai *Mean Absolute Percentage Error* (MAPE) dengan metode *k*-NN sebesar 23,37%. Sedangkan nilai MAD dengan metode *k*-NN-ANN sebesar 55,63 MW dan nilai MAPE dengan metode *k*-NN-ANN sebesar 5,58%. Sehingga, dapat disimpulkan bahwa peramalan daya listrik untuk satu jam ke depan menggunakan metode *k*-NN – ANN didapatkan hasil yang lebih baik.

Kata Kunci: *k*-Nearest Neighbour, Artificial Neural Network, Peramalan, Daya Listrik, Pembangkit Listrik Termal, *Mean Absolute Deviation*, *Mean Absolute Percentage Error*.

Abstract

The provision of planned electricity is very necessary to avoid excess or a large power shortage resulting from the power plant to supply consumer needs. Hybrid method *k*-Nearest Neighbor (*k*-NN) - Artificial Neural Network (ANN) is used in very short term forecasting of thermal power plant. This study aims to discuss the forecasting of the value of electric power that will be generated by targeted thermal power plant in the next hour. The thermal power plant which is the target of forecasting in this research is located adjacent to other thermal and hydro plants. The results showed the *Mean Absolute Deviation* (MAD) with the *k*-NN method was 246.61 MW and the *Mean Absolute Percentage Error* (MAPE) value with the *k*-NN method was 23.37%. While the value of MAD with the *k*-NN-ANN method was 55.63 MW and the MAPE value with the *k*-NN-ANN method was 5.58%. With the result that, it can be concluded that the forecasting of electric power for the next hour using the *k*-NN - ANN method obtained better results.

Keywords: *k*-Nearest Neighbour, Artificial Neural Network, Forecasting, Electrical Power, Thermal Power Plant, *Mean Absolute Deviation*, *Mean Absolute Percentage Error*.

PENDAHULUAN

Peramalan daya pembangkit tenaga listrik merupakan salah satu komponen penting sistem manajemen pembangkit tenaga listrik. Peramalan daya pembangkit tenaga listrik digunakan untuk mengambil keputusan unit commitment, penjadwalan pemeliharaan, penentuan kapasitas spinning reserve dan mencapai keandalan dari supply untuk mengoptimalkan biaya yang ekonomis.

Penyediaan daya listrik yang terencana sangat diperlukan karena energi listrik yang dihasilkan tidak bisa disimpan dan harus langsung digunakan. Maka dari itu, peramalan daya yang dibangkitkan diperlukan untuk

menghindari kelebihan atau kekurangan daya listrik yang besar hasil dari produksi daya listrik pembangkit listrik yang berfungsi sebagai pemasok kebutuhan konsumen.

Penelitian yang membahas peramalan daya listrik yang dibangkitkan oleh suatu pusat listrik menggunakan metode hybrid *k*-NN dengan ANN pernah dilakukan berjudul *k*-Nearest Neighbor Neural Network Models for Very Short-Term Global Solar Irradiance Forecasting Based on Meteorological Data membahas tentang peramalan daya listrik yang dibangkitkan Pusat Listrik Tenaga Surya yang dipengaruhi oleh daya listrik yang dibangkitkan oleh Pusat Listrik Tenaga Surya

yang lain yang berada di sekitar objek penelitian. (Chao Rong Chen dkk, 2016)

Algoritma k-NN merupakan algoritma yang melakukan klasifikasi berdasarkan kedekatan lokasi (jarak) suatu data dengan data yang lain. Prinsip kerja K-Nearest Neighbor (K-NN) sendiri adalah mencari jarak terdekat antara data yang dievaluasi dengan k tetangga terdekatnya dalam data pelatihan (Nugraha dkk, 2017).

Maka dari itu, peramalan daya yang dibangkitkan oleh Unit Pembangkitan Gresik dalam penelitian ini akan dipengaruhi oleh daya yang dibangkitkan oleh pembangkit tenaga listrik yang berada di dekat Unit pembangkitan Gresik yang berada di Regional Jawa Timur.

Artificial Neural Network (ANN) atau Jaringan Saraf Tiruan (JST) dipilih sebagai metode peramalan karena kemampuan Jaringan Saraf Tiruan dalam mengolah data yang tidak linier. Dengan perubahan kebutuhan daya listrik dari jam ke jam yang mengalami perubahan non linier, Jaringan Saraf Tiruan dinilai cocok untuk memeriksakan beban jangka pendek di hari berikutnya yang bersifat non linier setiap jamnya. Dengan proses pelatihan dan pengujian yang dilakukan, diharapkan terbangun pola Jaringan Saraf Tiruan untuk meramalkan beban di jam berikutnya.

Dari beberapa penelitian yang pernah ada maka, penulis mencoba melakukan penelitian di bidang ketenagalistrikan dengan mengombinasikan k-NN-ANN dalam peramalan jangka sangat pendek satu jam ke depan daya listrik yang dibangkitkan pembangkit termal dengan mempertimbangkan daya listrik yang dibangkitkan oleh pembangkit lain di sekitar pembangkit termal tersebut serta nilai temperatur dan kelembaban udara yang sedang berlangsung.

KAJIAN PUSTAKA

Peramalan Daya

Pusat Listrik tenaga Thermal memiliki tantangan secara berkelanjutan di bidang energi, lingkungan dan iklim. Di satu sisi, memiliki efek positif dari transformasi energi pada optimalisasi struktur energi, yang mengarah ke peningkatan konsumsi energi listrik secara cepat. Dalam refleksinya, jumlah daya yang dibangkitkan Pusat Listrik Tenaga Termal sebanding dengan jumlah polusi emisi yang dihasilkan. Berdasarkan dari sini, prediksi yang akurat bisa secara efektif menjadwalkan dan merencanakan daya pembangkit listrik yang akan dibangkitkan. Dan juga prediksi dapat meningkatkan keandalan dan mengurangi biaya operasi yang tinggi. (Li Shuyu, 2018)

Peramalan dapat melayani tujuan perencanaan yang berbeda dan membantu operator sistem untuk

memenuhi semua kondisi kritis di jangka pendek, menengah dan panjang. Hal ini dapat diklasifikasikan ke dalam empat jenis sehubungan dengan jendela waktu masa depan tugas peramalan (Setiawan dkk, 2009):

1. Jangka Panjang (*Long Term*)

Biasanya 1 sampai 10 tahun; digunakan untuk mengidentifikasi kebutuhan untuk perencanaan dan investasi generasi besar, sejak pembangkit listrik besar mungkin membutuhkan waktu satu dekade untuk tersedia karena persyaratan proyek yang menantang dan kebutuhan untuk merancang, membiayai dan membangunnya;

2. Jangka Menengah (*Medium Term*)

Biasanya antara beberapa bulan sampai tahun; digunakan untuk memastikan keamanan dan keterbatasan kapasitas terpenuhi dalam jangka menengah;

3. Jangka pendek (*Short Term*)

Sehari depan; digunakan untuk membantu perencanaan dan pelaku pasar;

4. Jangka Sangat Pendek (*Very Short Term*)

Jam dan menit ke depan; digunakan untuk membantu pemasaran dan penentuan pengiriman

Pembangkit Listrik Tenaga Thermal

Energi thermal adalah energi panas yang dapat diperoleh dari pembakaran bahan bakar, reaksi berantai didalam reactor nuklir, sinar matahari atau langsung dari dalam tanah berupa uap panas. Pengusahaan energi listrik dari energi thermal dilakukan dengan suatu proses tertentu didalam berbagai jenis pembangkit tenaga listrik seperti berikut (Rochani, 2013):

1. PLTD : Pembangkit Listrik Tenaga Diesel
2. PLTG : Pembangkit Listrik Tenaga Gas
3. PLTU : Pembangkit Listrik Tenaga Uap
4. PLTGU : Pembangkit Listrik Tenaga Gas Uap
5. PLTN : Pembangkit Listrik Tenaga Nuklir
6. PLTP : Pembangkit Listrik Tenaga Panas Bumi

Unit Pembangkit Gresik

Unit Pembangkitan (UP) Gresik setiap tahun membangkitkan energi listrik rata-rata 12.814 GWh yang disalurkan melalui Saluran Udara Tegangan Tinggi 150 kV dan Saluran Udara Tegangan Ekstra Tinggi 500 kV ke sistem interkoneksi Jawa, dan Bali. (PT PJB, 2015)

Tabel 1. Unit Pembangkit di UP Gresik

Unit Pembangkit	Daya Terpasang
PLTU Unit 1 dan Unit 2	2 x 100 MW
PLTU Unit 3 dan Unit 4	2 x 200 MW
PLGU Blok 1, Blok 2, dan Blok 3	3 x 526 MW
PLTG Unit 1 dan Unit 2	2 x 20 MW

Faktor-faktor Lingkungan terhadap Fungsi Generator

Kondisi suhu sekitar sangat penting untuk pengapian dan fungsi generator yang tepat. Semua generator, terlepas dari bahan bakar yang menggerakkan mereka, membutuhkan udara yang cukup untuk pembakaran. Penurunan level udara dapat menyebabkan kegagalan start-up. Dalam mesin diesel, udara dan bahan bakar dimasukkan bersama. Udara terkompresi menjadi panas dan ketika suhu dan tekanan puncak tercapai, diesel diinjeksikan, yang kemudian menyala di bawah kondisi yang diberikan. Dalam generator menggunakan bensin, campuran udara dan bahan bakar diperkenalkan sekaligus menggunakan karburator dan percikan terinduksi untuk menyalakan mesin. Namun dalam kedua kasus, tingkat udara yang memadai diperlukan untuk start up dan operasi yang tepat. (Anonim, 2018)

1. Ketinggian Permukaan Air Laut

Di daerah dataran tinggi, penurunan tekanan udara mengurangi densitas udara. Ini dapat menimbulkan masalah dengan start generator jika tidak diperhitungkan karena udara sangat penting untuk pengapian di semua jenis generator. Faktor lain yang terpengaruh adalah ketersediaan udara sekitar untuk memfasilitasi pembuangan panas dari generator. Banyak panas yang dihasilkan selama proses pembakaran dan harus dibuang ke lingkungan untuk mengurangi suhu mesin. Pada ketinggian yang tinggi, karena kepadatan udara yang rendah, pembuangan panas terjadi pada tingkat yang jauh lebih lambat daripada di permukaan laut, menghasilkan suhu mesin yang tinggi untuk jangka waktu yang berkelanjutan. Mesin tetap panas dan terlalu panas adalah masalah umum dalam kasus seperti itu.

2. Suhu Udara

Temperatur yang tinggi juga terkait dengan kepadatan udara yang lebih rendah dan dapat menyebabkan masalah pengapian yang sama karena pasokan udara yang tidak memadai. Ini dapat membebani mesin yang mendorong dirinya sendiri untuk memberikan kekuatan yang dirancang untuk itu. Namun, karena kadar oksigen yang tidak memadai yang tersedia untuk

pembakaran, ia gagal melakukannya. Dalam banyak kasus seperti itu, mesin menjadi terlalu panas.

3. Kelembaban

Kelembaban adalah ukuran kadar air dalam volume udara tertentu. Dalam kondisi kelembaban ekstrim, uap air di udara menggantikan oksigen. Tingkat oksigen rendah mengganggu pengapian, karena oksigen adalah unsur di udara yang dinyalakan dalam mesin untuk pembakaran bahan bakar.

k-Nearest Neighbor

Algoritma k-NN adalah algoritma yang melakukan klasifikasi berdasarkan kedekatan lokasi (jarak) suatu data dengan data yang lain. Prinsip kerja K-Nearest Neighbor (k-NN) sendiri adalah mencari jarak terdekat antara data yang dievaluasi dengan k tetangga terdekatnya dalam data pelatihan. (Nugraha dkk, 2017).

k-Nearest Neighbor (k-NN) adalah suatu metode yang menggunakan algoritma *supervised* dimana hasil dari *query instance* yang baru diklasifikasi berdasarkan mayoritas dari kategori pada k-NN. Tujuan dari algoritma ini adalah mengklasifikasikan obyek baru berdasarkan atribut dan *training sample*. *Classifier* tidak menggunakan model apapun untuk dicocokkan dan hanya berdasarkan pada memori. Diberikan titik *query*, akan ditemukan sejumlah *k* obyek atau (titik *training*) yang paling dekat dengan titik *query*. Klasifikasi menggunakan *voting* terbanyak diantara klasifikasi dari *k* obyek.. Algoritma k-NN menggunakan klasifikasi ketetanggaan sebagai nilai prediksi dari *query instance* yang baru. (Yovianto, 2010).

Sebelum mencari jarak terdekat antara data yang dievaluasi, pada algoritma k-NN harus dilakukan preprocessing atau normalisasi terlebih dahulu. Preprocessing sendiri bertujuan untuk mendapatkan standar nilai pada semua atribut atau indikator dalam perhitungan. Pada penelitian ini, normalisasi yang digunakan adalah *min-max normalization*. (Nugraha dkk, 2017).

Proses *min-max normalization* ditunjukkan dengan persamaan :

$$V' = \frac{v(x) - \min(x)}{\text{Range}(x)} \quad (1)$$

di mana:

V' = Hasil normalisasi yang nilainya berkisar antara 0-1

$v(x)$ = Nilai atribut yang akan dinormalisasikan

$\max(x)$ = Nilai maksimum dari suatu atribut $\max(x)$

$\min(x)$ = Nilai minimum dari suatu atribut $\min(x)$

$\text{Range}(x)$ = nilai dari $(\max(x) - \min(x))$

Setelah melakukan normalisasi, maka dilakukan proses perhitungan jarak terdekat antara data latih dan data uji. Perhitungan ini bertujuan agar mengetahui jarak antara x_1 dan x_2 pada masing-masing record. Perhitungan ini menggunakan *euclidean distance* seperti pada persamaan:

$$d_i = \sqrt{\sum_{i=1}^p (X_{2i} - X_{1i})^2} \quad (2)$$

di mana:

d_i = Jarak kedekatan

P = Jumlah atribut data

X_1 = Data latih

X_2 = Data uji

Artificial Neural Network (ANN) / Jaringan Saraf Tiruan (JST)

Jaringan Syaraf adalah merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia. Istilah buatan di sini digunakan karena jaringan syaraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran. (Kusumadewi, 2003)

Berikut beberapa istilah jaringan syaraf tiruan yang sering ditemui (Puspitaningrum, 2006):

1. *Neuron* atau *Node* : Sel saraf tiruan yang merupakan elemen pengolahan jaringan syaraf tiruan. Setiap *neuron* menerima data *input*, memroses *input* tersebut (melakukan sejumlah perkalian dengan melibatkan *summation function* dan fungsi aktivasi), dan mengirimkan hasilnya berupa sebuah output.
2. *Jaringan* : Kumpulan neuron yang saling terhubung membentuk lapisan
3. *Input* atau *Masukan* : Berkorespon dengan sebuah atribut tunggal dari sebuah pola atau data lain dari dunia luar. Sinyal-sinyal input ini kemudian diteruskan ke lapisan selanjutnya
4. *Output* atau *keluaran* : Solusi atau hasil pemahaman jaringan terhadap data input. Tujuan pembangunan jaringan syaraf tiruan sendiri adalah untuk mengetahui nilai output.
5. *Lapisan Tersembunyi (hidden layer)* : Lapisan yang tidak secara langsung berinteraksi dengan dunia luar. Lapisan ini memperluas kemampuan jaringan syaraf tiruan dalam menghadapi masalah-masalah yang kompleks.

6. *Bobot* : Bobot dalam jaringan syaraf tiruan merupakan nilai matematis dari koneksi, yang mentransfer data dari satu lapisan ke lapisan lainnya. Bobot ini digunakan untuk mengatur jaringan sehingga jaringan syaraf tiruan bisa menghasilkan output yang diinginkan sekaligus bertujuan membuat jaringan tersebut belajar.

7. *Summation Function* : Fungsi yang digunakan untuk mencari rata-rata bobot dari semua elemen input. Yang sederhana adalah dengan mengalikan setiap nilai input (X_j) dengan bobotnya (W_{ij}) dan menjumlahkannya (disebut penjumlahan berbobot, atau S_i). Untuk elemen *input summation function* dituliskan sebagai:

$$S_i = \sum_{j=1}^n W_{ij} * X_j \quad (3)$$

8. *Fungsi Aktivasi* : Fungsi yang menggambarkan hubungan antara tingkat aktivasi internal (*summation function*) yang mungkin berbentuk linear atau non linear. Beberapa fungsi aktivasi jaringan syaraf tiruan di antaranya : *hard limit*, *purelin*, dan *sigmoid*. Yang populer digunakan adalah fungsi *sigmoid* yang memiliki beberapa varian : *sigmoid biner*, *sigmoid bipolar*, dan *sigmoid tangen*.

Akurasi Peramalan

1. *Mean Absolute Deviation (MAD)*

Mean Absolute Deviation (MAD) adalah satu metode untuk mengevaluasi metode peramalan menggunakan jumlah dari kesalahan-kesalahan yang absolut. MAD mengukur ketepatan ramalan dengan merata-rata kesalahan dugaan (nilai absolut masing-masing kesalahan). (Winita, 2011)

Semakin besar nilai MAD, menunjukkan model yang dihasilkan kurang tepat. MAD merupakan nilai absolut penjumlahan dari kesalahan, baik positif dan negatif, sehingga dapat menambah jumlah dan ukuran rata-rata dari kesalahan yang ditentukan. (Amperajaya, 2013)

Rumus untuk menghitung MAD adalah:

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (4)$$

dengan:

n = jumlah data.

Y_t = nilai aktual pada periode waktu t .

\hat{Y}_t = Nilai ramalan untuk periode waktu t

2. Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah metode lain untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau sisa dikuadratkan. Kemudian dijumlahkan dan dibagi dengan jumlah observasi. Pendekatan ini mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan. Suatu teknik yang menghasilkan kesalahan moderat mungkin lebih baik untuk salah satu yang memiliki kesalahan kecil tapi kadang-kadang menghasilkan sesuatu yang sangat besar. (Winita, 2011)

Rumus untuk menghitung MSE adalah

$$MSE = |MAD|^2 \quad (5)$$

3. Mean Absolute Percent Error (MAPE)

Mean Absolute Percentage Error (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, meratarata kesalahan persentase absolut tersebut. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan itu penting dalam mengevaluasi ketepatan ramalan. MAPE mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai nyata pada deret. (Winita, 2011)

Masalah yang terjadi dengan MAD dan MSE adalah bahwa nilai kesalahan tergantung pada besarnya unsur yang diramal, jika unsurnya dalam satuan ribuan, maka nilai kesalahan bisa menjadi sangat besar. MAPE digunakan untuk menghindari masalah tersebut, yang dihitung sebagai rata-rata diferensiasi absolut antara nilai yang diramal dan aktual, yang dinyatakan dalam persentase nilai aktual. (Amperajaya, 2013)

Rumus untuk menghitung MAPE adalah

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{\hat{Y}_t} \times 100 \% \quad (6)$$

METODE

Pendekatan penelitian ini dilakukan dengan metode penelitian eksperimen dengan pendekatan kuantitatif. Penelitian kuantitatif adalah suatu proses menemukan pengetahuan yang menggunakan data berupa angka sebagai alat menemukan keterangan mengenai apa yang ingin kita ketahui. (Darmawan, 2014),

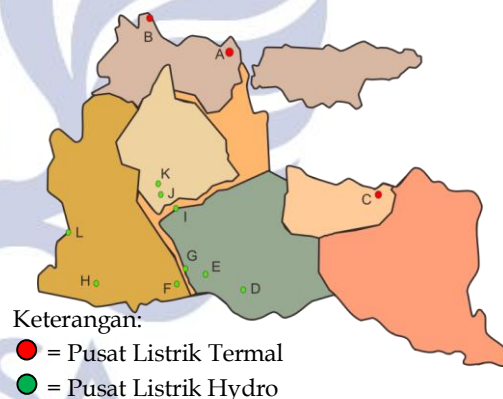
Metode kuantitatif adalah metode penelitian yang berlandaskan pada filsafat positivisme, digunakan untuk

meneliti populasi atau sampel tertentu. Pendekatan eksperimen merupakan metode penelitian yang digunakan untuk mencari pengaruh perlakuan tertentu terhadap yang lain dalam kondisi yang terkendali. (Sugiyono, 2015)

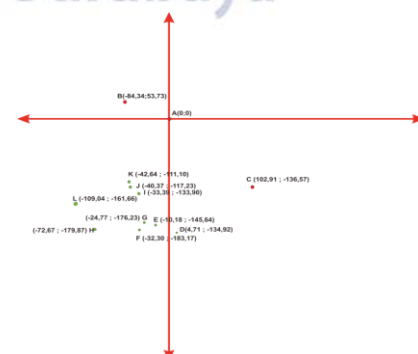
Dalam penelitian ini, mencoba menemukan hasil persamaan polinomial yang baik dalam proses k-NN dan mencoba-coba model training, variasi jumlah neuron, dan variasi jumlah epoch dalam proses ANN yang kemudian akan ditemukan hasil output yang terbaik dalam melakukan peramalan.

Prosedur Penelitian

Dalam metode k-NN, posisi titik-titik penentu dari objek yang akan diteliti harus diketahui. Pertama, didapatkan peta kelistrikan PT PJB regional Jawa Timur. Dari peta tersebut dapat digambarkan penyebaran pembangkitan PT. PJB di Jawa Timur seperti pada Gambar 1. Setelah itu, dibuat suatu garis kordinat X dan Y untuk menentukan letak kordinat pusat listrik-pusat listrik lain yang merupakan tetangga terdekat dari PLTGU Gresik yaitu PLTU Tanjung Awar-Awar, , PLTU Paiton dan PLTA UP Brantas seperti pada Gambar 2.



Gambar 1. Peta Penyebaran Pembangkitan Region Jawa Timur
(Sumber: Data Primer, 2018)

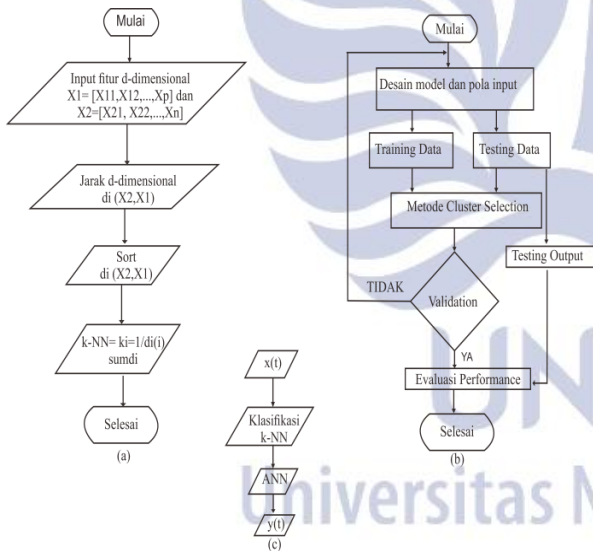


Gambar 2. Titik Kordinat Penyebaran Pembangkit yang Telah Ditentukan
(Sumber: Data Primer, 2018)

Dalam perencanaan penelitian peramalan daya listrik yang dibangkitkan oleh PLTGU UP Gresik direncanakan secara sistematis seperti yang ditunjukkan pada Gambar 3. Dan untuk peramalan, dibuat secara sistematis untuk metode k-NN-ANN seperti pada flowchart Gambar 4.



Gambar 3. Flow Chart Penelitian
(Sumber: Data Primer, 2018)



Gambar 4 Flow Chart Penelitian dengan (a) merupakan proses k-NN; (b) proses ANN, dan (c) model hybrid k-NN-ANN
(Sumber: Chen & Kartini, 2017)

Pembangkit Jawa Bali (PJB) yang berada di region Jawa Timur. Data yang digunakan adalah data daya yang dibangkitkan, data jumlah bahan bakar, data suhu dan kelembaban udara di daerah pembangkit berada. Data-data yang ada tersebut diklasifikasikan menggunakan metode k-Nearest Neighbor dengan rumus:

$$d_i = \sqrt{\sum_{i=1}^p (X2_i - X1_i)^2} \quad (7)$$

di mana:

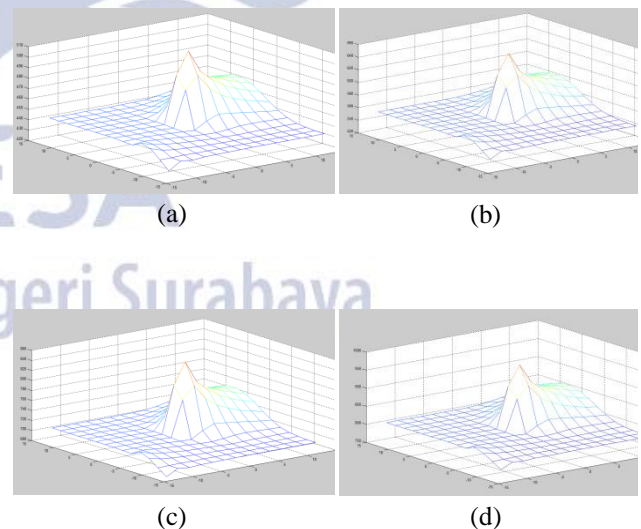
d_i = Jarak kedekatan
 p = Jumlah atribut data
 $X1$ = Data latih
 $X2$ = Data uji

Kemudian menghitung jumlah tetangga terdekat k dengan rumus:

$$k = \frac{1}{d_i} \quad (8)$$

Persamaan Polinomial k-Nearest Neighbor

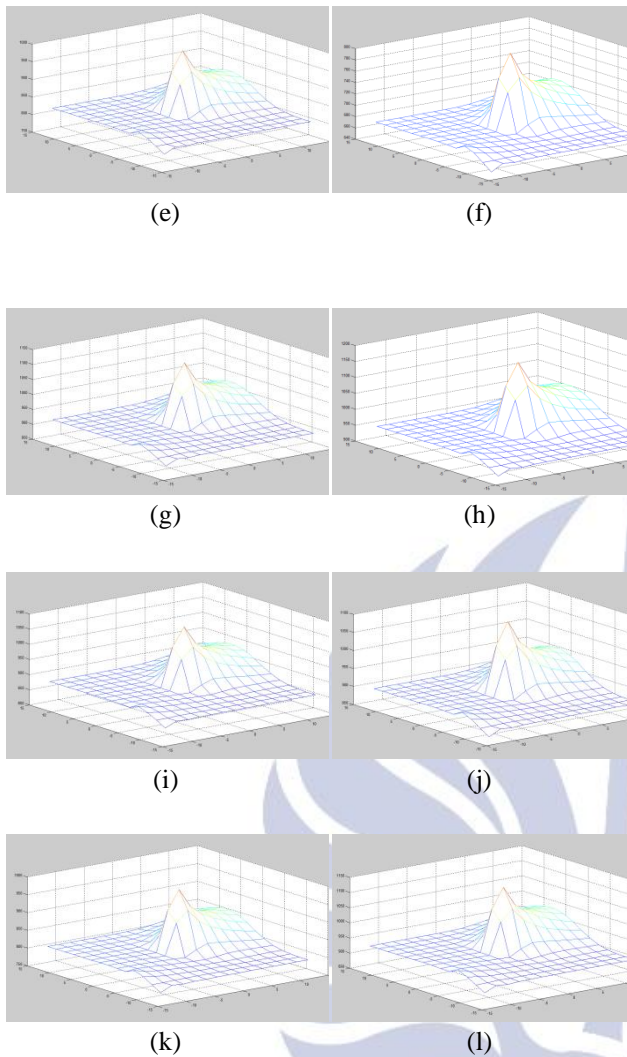
Klasifikasi data yang dilakukan menggunakan metode k-Nearest Neighbor akan diubah ke dalam bentuk persamaan. Persamaan yang digunakan adalah persamaan polinomial dengan orde 1. Tiap jam dari pengklasifikasian k-Nearest Neighbor menghasilkan persamaan yang berbeda-beda. Hal tersebut dapat dilihat padagrafik di Gambar 5 di bawah.



HASIL DAN PEMBAHASAN

Klasifikasi Data k-Nearest Neighbor

Pada penelitian ini, data dari pusat listrik-pusat listrik yang sebagai tetangga terdekat di sekitar PLTGU Gresik dikelompokkan. Pusat-pusat listrik yang dijadikan tetangga terdekat dalam penelitian ini adalah pusat listrik yang berada di bawah pengelolaan PT



Gambar 5 Grafik Hasil Klasifikasi k-NN
Setiap Satu Jam

- (a) Pukul 07.00, (b) Pukul 08.00, (c) Pukul 09.00,
(d) Pukul 10.00, (e) Pukul 11.00, (f) Pukul 12.00,
(g) Pukul 13.00, (h) Pukul 14.00, (i) Pukul 15.00,
(j) Pukul 16.00, (k) Pukul 17.00, (l) Pukul 18.00
(Sumber: Data Primer, 2018)

Pencarian persamaan menggunakan bantuan tool dari matlab yaitu *curve fitting tool*. Dari *curve fitting tool* ini akan menghasilkan persamaan polinomial orde satu yaitu:

$$P = p00 + p10x + p01y \quad (9)$$

$p00$ merupakan nilai konstanta, $p10$ merupakan nilai pengali dari koordinat x , dan nilai $p01$ merupakan nilai pengali dari koordinat y . Pengklasifikasian data yang dilakukan akan menghasilkan nilai $p00$, $p10$, dan $p01$ yang berbeda-beda tiap jamnya. Hal ini dikarenakan data tiap jam yang digunakan juga berbeda-beda. Persamaan polinomial yang dihasilkan mulai dari pukul

07.00 sampai dengan pukul 18.00. Hasil dari persamaan polinomial orde satu yang sudah didapat selanjutnya dicari nilai aslinya dengan mensubstitusi variabel x dan y masing-masing persamaan polinomial.

Hasil Peramalan Hybrid k-Nearest Neighbor-Artificial Neural Network


Hasil dari k-Nearest Neighbour selanjutnya dimasukkan ke dalam proses hybrid k-Nearest Neighbour-Artificial Neural Network. Sebelum dimasukkan ke dalam Neural Network, hasil k-Nearest Neighbour terlebih dahulu dinormalisasi menggunakan rumus persamaan 1.

Model pelatihan yang digunakan dalam *artificial neural network feed forward propagation* adalah model dua step. Model ini memodelkan pelatihan dengan dua data input di setiap satu target. Misalkan data input training adalah pukul 07.00 dan 08.00, maka data target adalah pukul 09.00. Hasil pelatihan menunjukkan hasil error 0,03. Hasil ini mendekati dengan target error yang ditentukan yaitu 0,01.


Setelah tahap pelatihan, dilakukan tahap pengujian. Tahap pengujian ini merupakan implementasi dari model jaringan yang sudah dilatih dalam proses pelatihan. Tahap pengujian ini menggunakan data hasil *k-Nearest Neighbour* sebagai data input dan data aktual dari PLN sebagai data target. Data yang digunakan adalah data mulai pukul 07.00 sampai dengan pukul 18.00 yang selanjutnya akan meramalkan data pada pukul 19.00 yang merupakan data daya yang diramalkan akan dibangkitkan oleh PLTGU Gresik. Hasil dari k-NN dan k-NN-ANN mulai pukul 07.00 sampai dengan pukul 18.00 terdapat pada Tabel 1. Perbandingan hasil *k-Nearest Neighbour* (k-NN) dan hasil k-NN-ANN dengan data asli tersaji seperti pada Gambar 6.

Tabel 1 Hasil k-NN dan k-NN-ANN dengan Data Asli PLN

	PLN (MW)	k-NN (MW)	kNN-ANN 2 STEP 10 LAYER (MW)
Pukul			
07.00	549,9	446,41607	492,8040162
08.00	708,5	560,66446	654,4728778
09.00	927,4	715,6339	893,7356754
10.00	1074,7	817,6829	1012,384403
11.00	1093,3	831,0886	1018,182223
12.00	874,8	679,5161	855,4277257
13.00	1236,9	930,7362	1182,66683
14.00	1283,7	962,5524	1212,463964
15.00	1181,8	892,1184	1124,716737
16.00	1206,6	909,2267	1135,806967
17.00	1074,3	817,5825	1012,325437
18.00	1249,9	939,241	1199,217698



Gambar 6. Grafik Perbandingan Hasil k-NN, k-NN-NN, dan Data Asli.




Gambar 7 Hasil Peramalan pada Pukul 19.00

Dalam Gambar 7 ditunjukkan hasil peramalan daya yang dibangkitkan PLTGU Gresik pada pukul 19.00. Hasil peramalan menunjukkan hasil 1212,463 MW yang diramalkan harus dibangkitkan PLTGU Gresik pada pukul 19.00.

Tingkat keakurasian dari metode k-NN-ANN dengan k-NN dapat dilihat dari nilai *Mean Absolute Deviation* (MAD) dan *Mean Absolute Percentage Error* (MAPE). Grafik MAD dan MAPE tersaji pada Gambar 8 dan Gambar 9.


Mean Absolute Deviation (MAD) merupakan nilai absolut error dari pengujian dengan data asli. Hasil pengujian yang dimaksud adalah hasil yang ditampilkan oleh k-NN dan k-NN-ANN pada pukul 07.00 sampai dengan pukul 18.00 sebagai data pendukung untuk peramalan pada pukul 19.00. Sedangkan *Mean Absolute Percentage Error* (MAPE) adalah nilai persentase error absolut hasil pengujian dengan nilai data asli.



Gambar 8 Mean Absolute Deviation (MAD) k-NN dan k-NN-ANN

Pada Gambar 8, dapat dilihat bahwa nilai MAD k-NN-ANN memiliki rata-rata lebih rendah dari k-NN. Rata-rata nilai MAD k-NN adalah 246,61 MW. Sedangkan rata-rata nilai MAD k-NN-ANN adalah 55,63 MW. Hal ini berarti nilai error yang didapatkan dari hasil k-NN-ANN lebih kecil. Sehingga tingkat keakurasian k-NN-ANN lebih tinggi.

Pada Gambar 9, terhitung nilai rata-rata MAPE k-NN adalah 23,37%. Sedangkan nilai rata-rata MAPE k-NN-ANN terhitung 5,58%. Dari hasil ini berarti ANN memperbaiki kinerja dari metode k-NN. Sehingga hasil dari k-NN-ANN yang bernilai MAPE rata-rata 5,58% dapat dijadikan acuan untuk meramalkan daya yang dibangkitkan oleh PLTGU Gresik satu jam ke depan.



Gambar 9 Mean Absolute Percentage Error (MAPE) k-NN dan k-NN-ANN.

PENUTUP Simpulan

Dari hasil penelitian yang dilakukan, dapat disimpulkan bahwa k-NN menghasilkan nilai yang jauh lebih rendah dengan data asli seperti yang tersaji pada Gambar 8 dengan nilai rata-rata MAD 246,61 MW dan pada Gambar 9 rata-rata MAPE sebesar 23,37%. ANN

digunakan untuk mengatasi nilai error yang besar yang dihasilkan oleh k-NN. Sehingga metode hybrid k-NN-ANN cukup akurat untuk meramalkan daya yang dibangkitkan oleh PLTGU UP Gresik satu jam ke depan. Nilai rata-rata MAD k-NN-ANN pada Gambar 7 sebesar 55,63 MW dan MAPE k-NN-ANN pada Gambar 8 sebesar 5,58% jauh lebih baik dari k-NN. Dan nilai daya yang dihasilkan oleh hasil peramalan metode hybrid k-NN-ANN untuk satu jam ke depan atau pada pukul 19.00 adalah sebesar 1212,463 MW.

Saran

Dari hasil penelitian yang didapat, dapat disarankan untuk penelitian selanjutnya penggunaan metode k-NN-ANN dalam peramalan metode k-NN-ANN memperbanyak step yang yang digunakan dengan variasi jumlah neuron yang mungkin bisa mendapatkan hasil yang lebih baik.

DAFTAR PUSTAKA

- Amperajaya, Derajat .2013.”Peramalan (Forecasting)”. Tersedia:<http://www.ema302.weblog.esaungul.ac.id/> (diakses tanggal 9 Juli 2018)
- Chen, Chao-Rong & Kartini, Unit Three. 2017. ” k-Nearest Neighbor Neural Network Models for Very Short- Term Global Solar Irradiance Forecasting Based on Meteorological Data”. *Department of Electrical Engineering, National Taipei University of Technology, 1, Section 3*, (8 Februari 2017)
- Darmawan, Deni. 2014. *Metode Penelitian Kuantitatif*. Bandung : Remaja Rosdakarya
- Kusumadewi, Sri.2003. *Artificial Intelligence (Teori dan Aplikasinya)*. Yogyakarta : Graha Ilmu.
- Li Shuyu,dkk.2018.”Forecasting China’s Coal Power Installed Capacity: A Comparison of MGM, ARIMA, GM-ARIMA, and NMGM Models”. *Sustainability* 2018, 10(2), 506.
- Nugraha S.D, Putri R.R.M, & Wihandika R.C.2017. “ Penerapan Fuzzy K-Nearest Neighbor (FK-NN) Dalam Menentukan Status Gizi Balita”.*Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 1, No. 9, Juni 2017.
- PT PJB.2015. “Unit Pembangkitan Gresik”. Tersedia : <http://www.ptpjb.com/index.php/id/gresik/up-gresik> (diakses tanggal 16 Februari 2018)
- Puspitaningrum, Diyah.2006. *Pengantar Jaringan Saraf Tiruan*. Yogyakarta : Penerbit Andi.
- Rochani, Habib.2013. *Pembangkit Listrik Tenaga Thermal I (PLTU & PLTP)*. Jakarta : Sekolah Tinggi Teknik PLN
- Setiawan, Koprinska, dan Agelidris.2009. “Very Short-Term Electricity Load Demand Forecasting Using Support Vector Regression”. 31 July 2009
- Sugiyono.2015. *Metode Penelitian Pendidikan (Pendekatan Kuantitatif, Kualitatif, dan R&D)*. Bandung: ALFABETA.
- Winita.2011. “Pemilihan Teknik Peramalan dan Penentuan Kesalahan Peramalan”. Tersedia: <http://winita.staff.mipa.uns.ac.id/> (diakses tanggal 9 Juli 2018)
- Yovianto, Evan.2010. “Buku TA: K-Nearest Neighbor (KNN)”. Tersedia <https://kuliah.informatika.wordpress.com/2010/02/13/buku-ta-k-nearest-neighbor-knn/> (diakses tanggal 16 Februari 2018)
- Anonim.2018.”Factors Affecting Generator Output Rating”. Tersedia:https://www.dieselserviceandsupply.com/Generator_Output_Rating.aspx (diakses tanggal 29 Agustus 2018)